

Previsão de Geração de Energia Fotovoltaica Utilizando Transformação de Séries Temporais em Imagens e Redes Neurais Convolucionais

Diego Ramiro Melo Monteiro
Programa de Pós-Graduação em Engenharia Elétrica - PPGEE
Universidade Federal do Pará - UFPA
Belém, Brasil
diego.monteiro@itec.ufpa.br

Adriana Rosa Garcez Castro
Programa de Pós-Graduação em Engenharia Elétrica - PPGEE
Universidade Federal do Pará - UFPA
Belém, Brasil
adcastro@ufpa.br

Resumo— Este artigo apresenta uma nova abordagem baseada em Rede Neural Convolucional Bidimensional (*Convolutional Neural Network* – CNN) e Gráfico de Recorrência (*Recurrence Plot* – RP) para previsão em curto prazo da geração de energia elétrica de uma microssistema fotovoltaica conectada à rede elétrica, localizada no Centro de Excelência em Eficiência Energética da Amazônia-CEAMAZON, da Universidade Federal do Pará (UFPA). O gráfico de recorrência foi utilizado para transformação das séries temporais em imagens para serem utilizadas como entrada para a CNN. A previsão de geração de energia elétrica com maior precisão possibilita ao usuário conhecer com maior grau de acerto quais os possíveis custos para implantação da rede e os prazos para retorno financeiro, além de avaliar com maior assertividade a disponibilidade de carga que poderá ser conectada ao sistema. Os resultados da previsão com a utilização da CNN 2D e RP foram comparados com resultados utilizando outros tipos de rede neurais já consolidadas na área, tendo obtido valores RMSE satisfatórios, da ordem de 1,85% menor que o erro obtido com a *Perceptron* Multicamadas e 3,03% menor que o RMSE da CNN 1D, mostrando assim a sua aplicabilidade para o problema.

Palavras-Chave—geração de energia fotovoltaica, redes neurais convolucionais, gráfico de recorrência, séries temporais, previsão, inteligência computacional.

INTRODUÇÃO

A corrida para minimizar os impactos nocivos do aquecimento global tem direcionado a discussão acerca da utilização de fontes renováveis de energia elétrica para o desenvolvimento das sociedades. Tão importante é o assunto que dentre os 17 objetivos estabelecidos pela Organização das Nações Unidas – ONU para possibilitar o desenvolvimento sustentável do planeta está o de garantir o acesso a energia limpa e barata a todos os povos [1].

Diante da necessidade urgente na utilização de fontes limpas e renováveis de energia elétrica, destaca-se a relevância da geração de energia elétrica fotovoltaica, por apresentar maior densidade de potência e pelas características técnicas que permitem grande aproveitamento na geração descentralizada [2].

Em virtude desse novo horizonte, onde se espera um avanço significativo das instalações de sistemas fotovoltaicos, tanto em edificações residenciais de pequeno porte quanto de instalações de médio e grande porte, faz-se necessário encontrar técnicas mais aprimoradas para contornar as características estocásticas da energia gerada por fonte solar, principalmente ocasionadas pela movimentação de nuvens, as quais reduzem ou bloqueiam a incidência de raios solares nos sistemas fotovoltaicos, inserindo incertezas na entrega de energia elétrica.

Conhecer a quantidade de energia elétrica gerada por sistemas fotovoltaicos em horizontes de curto, médio ou longo prazo, de maneira mais precisa possível, garante o funcionamento eficiente do gerenciamento de despacho de energia, minimizando custos com armazenamento, além de melhor operar sistemas distribuídos, microrredes, casas inteligentes ou redes elétricas inteligentes, bem como para possibilitar melhor controle e planejamento pelos usuários finais e pelos operadores do sistema [3].

Dentro da área de aprendizado de máquina, as Redes Neurais Artificiais (RNA) são técnicas que vêm sendo bastante utilizadas na área de previsão de geração de energia fotovoltaica, tendo se mostrado eficientes e com resultados promissores. O sucesso do uso das RNAs na área de previsão se deve principalmente à capacidade que elas apresentam de aprender funções não lineares e a capacidade de generalização [4].

Dentre os tipos de RNAs utilizadas para previsão, o mais empregado na literatura, segundo [4], é a Rede Perceptron Multicamadas (MLP – *Multilayer Perceptron*). Alguns autores também vêm utilizando, com resultados promissores, as Redes Neurais Convolucionais 1D para o processo de previsão [5][6][7]. Além dessas técnicas, encontrou-se na literatura a utilização da arquitetura *Long Short Term Memory* (LSTM) isoladamente e em combinação com outras técnicas [8][9][10].

Considerando a importância da previsão de geração de energia fotovoltaica e a capacidade das redes neurais artificiais, este trabalho apresenta a proposta de uma nova abordagem para o problema, baseada em Rede Neural Convolucional 2D e Gráfico de Recorrência (RP). Utilizando estas duas ferramentas, foi desenvolvido, com base em dados históricos de energia gerada de um período de 2 anos (2021-2022), um sistema para a previsão de geração de energia fotovoltaica para o dia seguinte para um sistema fotovoltaico instalado no Centro de Excelência em Eficiência Energética da Amazônia-CEAMAZON, da Universidade Federal do Pará (UFPA). O sistema de previsão se baseia no uso de Gráfico de Recorrência para transformação da informação no domínio do tempo das séries temporais em imagens para serem utilizadas como entrada para uma CNN 2D para previsão, sendo que o uso da CNN 2D visou explorar todo o potencial de processamento de imagens e extração de características deste tipo de rede.

O trabalho busca apresentar a viabilidade da previsão de geração de energia fotovoltaica usando séries temporais em formato de imagens através da utilização de uma CNN 2D, sendo que os resultados obtidos foram comparados com as

respostas de redes MLP e CNN 1D, que utilizam a série temporal direta, sem transformação para imagem.

O restante do artigo está organizado da seguinte maneira: A fundamentação teórica é explanada na Seção II, enquanto na Seção III é apresentada a metodologia adotada no presente estudo. Na Seção IV são apresentados os resultados alcançados e, por fim, na Seção V tem-se as conclusões acerca do método de previsão proposto neste trabalho.

FUNDAMENTAÇÃO TEÓRICA

A. Energia Solar

O Sol é uma poderosa fonte de energia, emitindo a cada hora cerca de 100.000 TW à superfície terrestre, o que seria suficiente, segundo [11], para suprir o consumo energético do mundo todo por cerca de um ano.

A energia solar é amplamente aproveitada através de conversão termal e de conversão fotovoltaica. Enquanto na primeira a energia solar é convertida na forma de calor, tanto para utilização final quanto para aproveitamento para geração de energia térmica, a qual posteriormente pode resultar na realização de trabalho, na conversão fotovoltaica a energia solar é transformada em energia elétrica através da excitação de elétrons em células solares compostas por materiais semicondutores [12].

B. Previsão de Geração Fotovoltaica

Estimar a quantidade de energia elétrica a ser gerada por sistemas fotovoltaicos se tornou uma etapa de grande importância no planejamento do mercado de energia em virtude do impacto relevante que tais informações causam na operação e na gestão de sistemas de energia elétrica.

Em virtude de as condições climáticas afetarem diretamente a quantidade de energia gerada em um determinado sistema fotovoltaico, tais como a irradiação solar e temperatura, dentre outros, a energia gerada por estes sistemas apresenta variação dinâmica ao longo do tempo. A variação na energia entregue por sistemas fotovoltaicos conectados à rede elétrica, e sua consequente imprevisibilidade, afeta negativamente a estabilidade do sistema, bem como aumenta os custos operacionais por incrementar a necessidade de utilização das reservas primárias de energia elétrica [13].

Sobre a maneira de abordagem da previsão de geração de energia fotovoltaica, os métodos amplamente utilizados são a previsão indireta, quando são realizadas preliminarmente estimativas da irradiação solar, para posteriormente, e com utilização de modelagens matemáticas, realizar a previsão da energia a ser gerada em um determinado horizonte de tempo, e a previsão direta, quando a técnica utilizada para previsão estima a quantidade de energia elétrica que será entregue pelo sistema em análise [14].

As quatro principais técnicas utilizadas para a realização da previsão de geração de energia fotovoltaica podem ser classificadas nas seguintes categorias: métodos físicos, modelos estatísticos, técnicas de inteligência artificial e os modelos híbridos [15]. Métodos de inteligência artificial, como os modelos de Aprendizado de Máquina (*Machine Learning* – ML), conseguem superar a deficiência dos modelos estatísticos por terem a possibilidade de trabalhar com não-linearidades nas relações entre as entradas e saídas, além de apresentarem boa performance. Outros pontos de destaque são a capacidade de generalização e de trabalhar

com informações complexas e com grande quantidade de amostras.

C. Redes Neurais Artificiais

As RNAs são métodos de aprendizagem de máquina que modelam a maneira de funcionamento do cérebro humano em determinadas tarefas ou funções, sendo definidas em [16] como um processador massivo de distribuição paralela criado a partir de unidades simples de processamento que possuem propensão natural ao armazenamento de conhecimento experimental, com grandes semelhanças ao funcionamento do cérebro humano.

Uma RNA possuiu alto poder de generalizar informações após uma fase de aprendizagem, possibilitando capturar relações funcionais entre os dados, produzindo uma saída próxima aos valores esperados [17].

Dentre as redes neurais artificiais, as redes Perceptron Multicamadas e as Redes Neurais Convolucionais vêm sendo bastante utilizadas para o problema de previsão de geração de energia fotovoltaica.

As redes Perceptron Multicamadas (*Multi Layer Perceptron* – MLP) são caracterizadas pela presença de pelo menos uma camada intermediária de neurônios artificiais entre as camadas de entrada e de saída. Nesta arquitetura, o fluxo de informações se inicia na camada de entrada, a qual envia estímulos à camada intermediária imediatamente posterior, propagando este sinal a diante até sensibilizar os neurônios na camada de saída [17].

As CNNs, um tipo especializado de RNA, são comumente utilizadas para processamento de dados com formato característico tabular, tais como imagens, vídeos ou ainda informações em forma de série temporal. Tais redes apresentam vantagens sobre outros sistemas de aprendizado de máquina, tais como: captação de dependências espaciais e temporais; e compartilhamento de parâmetros e consequente redução do número de parâmetros [18]. Segundo [19], as CNNs são compostas de camadas convolucionais e camadas de *pooling*. As camadas convolucionais são responsáveis pela extração de elementos e padrões que descrevam o conteúdo dos dados repassados pela camada de entrada ou pela camada anterior. Os dados da entrada das camadas convolucionais passam por convolução com filtros, cujo tamanho é menor que os dados originais e cujos valores inseridos passarão por atualização durante o processo de aprendizagem, e por função de ativação com não-linearidade. Já as camadas de *pooling* recebem as informações provenientes da camada anterior e as sintetizam, agrupando características extraídas que sejam semelhantes.

Após a extração das principais características e informações relevantes, por meio das camadas convolucionais e de *pooling*, das imagens apresentadas às redes convolucionais, às saídas das CNNs são colocadas camadas totalmente conectadas, as quais possuem estruturas semelhantes às configurações de redes MLPs. No presente trabalho, os neurônios da camada de saída indicarão os valores de energia gerada preditos pela rede.

D. Transformação de Séries Temporais em Imagens

Séries temporais são quaisquer conjuntos de observações de uma ou mais variáveis ordenadas no tempo, em que haja uma dependência entre instantes de tempo consecutivos [20]. Uma maneira de visualizar a natureza periódica de uma trajetória ao longo do espaço de fase, além de representar as

correlações, padrões e características escondidos no comportamento temporal de um determinado sistema, é através do uso de Gráficos de Recorrência, técnica esta proposta em [21], com capacidade de detectar não-linearidades e todas as informações dinâmicas relevantes da série temporal analisada.

Considerando-se uma série temporal:

$$\hat{x}_i = (x_i, x_{i+\tau}, \dots, x_{i+\tau+N}) \quad (1)$$

onde x_i é o valor da série temporal no instante i , τ é o passo de atraso e N é a dimensão de alcance da série temporal a ser utilizada, o Gráfico de Recorrência sem limiar dessa série temporal de $N+1$ pontos é a matriz de recorrência R , de tamanho $N \times N$, onde um ponto $R_{i,j}$ denota a distância entre os estados no espaço de fases [22].

A recorrência é representada por:

$$R_{i,j} = \|\hat{x}_i - \hat{x}_j\| \quad (2)$$

onde $\|\cdot\|$ é a norma euclidiana da distância a partir do estado \hat{x}_i . Para ilustração do uso da RP, as fig. 1 e 2 apresentam séries temporais para um e três dias de geração de energia fotovoltaica, respectivamente, enquanto as fig. 3 e 4 demonstram a representação dos gráficos de recorrência das séries temporais correlatas.

METODOLOGIA

O enfoque do presente trabalho é a energia elétrica gerada pela mini usina de geração fotovoltaica instalada nas dependências do CEAMAZON, na UFPA, localizado em Belém/PA, nas coordenadas 1,4668 S e 48,447 W. O sistema em questão possui três plantas fotovoltaicas, sendo o SFV-CEAMAZON 01, de 58 KWp, o SFV-CEAMAZON 02, de 16 KWp e o SFV-CEAMAZON 03, de 8 KWp, além de um grupo gerador a diesel e banco de baterias, conforme detalhado em [23] e ilustrado na fig. 5.

A. Sistema Fotovoltaico

A planta adotada para o desenvolvimento das análises do presente projeto foi a SFV-CEAMAZON 02, por possuir a maior quantidade de dados disponíveis no período dos anos de 2021 a 2022. Tal sistema é composto por módulos fotovoltaicos instalados em suportes de solo, com inclinação azimutal de 12° e alinhamento norte, além de um inversor de frequência trifásico de 15 KW. A planta em análise é utilizada para garantir o suprimento de energia elétrica às cargas instaladas no prédio do CEAMAZON.




Fig. 1. Série temporal de 24 horas

Fig. 2. Série temporal de 72 horas

RP - Energia Gerada em 07/01/2021




Fig. 3. RP de 24 horas

RP - Energia Gerada em 07 a 09/01/2021




Fig. 4. RP de 72 horas

B. Base de Dados

Os dados provenientes do equipamento de registro de dados do sistema do CEAMAZON (série histórica) são tomados minuto a minuto, sendo compostos pela data completa (dia, mês, ano e hora), tensão por fase, corrente por fase e potência ativa instantânea por fase.

A base de dados disponibilizada pelo CEAMAZON corresponde ao período de 01 de janeiro de 2021 a 31 de dezembro de 2022.

As informações a serem utilizadas da base de dados correspondem às potências ativas por fase do SFV-CEAMAZON 02, as quais passaram pelo devido tratamento, de tal forma que os dados usados para treinamento das redes neurais foram a energia elétrica total horária gerada pelo sistema.

C. Pré-Processamento dos Dados

Considerando que o alvo do presente estudo é a previsão da geração fotovoltaica do dia seguinte da planta em enfoque, os dados de saída do sistema, a saber, as potências ativas por fase, cuja unidade medida é watt (W), foram primeiramente somadas e divididas por 1.000, minuto a minuto, de tal modo a se obter a potência ativa instantânea trifásica em quilowatt (KW).

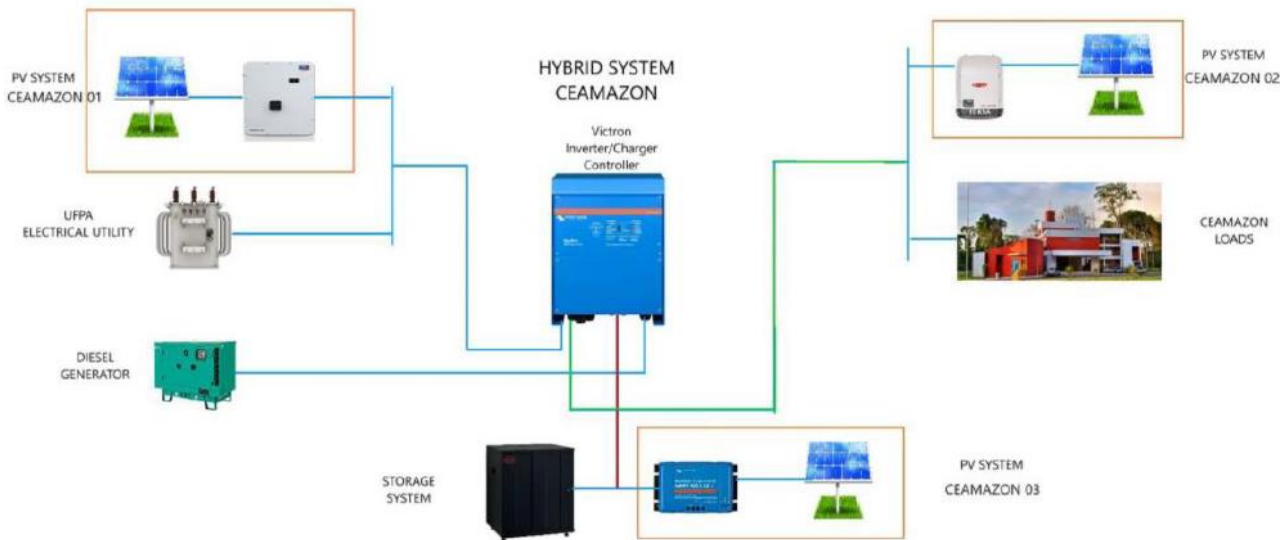


Fig. 5. Componentes do Sistema Híbrido do CEAMAZON [23]

Posteriormente, cada entrada de potência ativa trifásica por minuto foi transformada em energia, cuja unidade é quilowatt-hora (KWh), através da multiplicação do valor da potência ativa trifásica por 1/60. Após isso, os valores foram integralizados em 1 hora através da soma de cada valor de energia dos minutos pertencentes à respectiva hora.

Os dias sem registros de geração de energia, geralmente ocasionados por falha de captação decorrente de problemas na rede de dados ou no equipamento responsável pelo registro (*datalogger*), foram excluídos integralmente, bem como as entradas com menos de 9 horas de dados de geração de energia dentre o horário ativo de irradiação solar, a saber, das 06 às 18h.

Após a remoção dos dados faltosos ou inconsistentes, contabilizaram-se os dados de energia gerada em 674 dias. Para efeitos de treinamento e teste, os dados foram divididos na proporção 80/20, onde 80% dos dados disponíveis foram utilizados para o treinamento, a saber, dados de 535 dias, e 20% dos dados, ou seja, 139 dias, para teste.

Utilizou-se, para validação do modelo, a técnica de validação cruzada *Holdout* com parada antecipada, onde, dentre os 80% dos dados disponibilizados para treinamento, 10% foram utilizados para validação e os 90% restantes foram usados para o treinamento em si. Tais dados de validação correspondem ao trecho final da série temporal de treinamento, com o objetivo de, simultaneamente, evitar o sobre-treinamento da rede e garantir que os dados de validação mantenham as dependências temporais do sinal de entrada apresentado à rede. A avaliação do desempenho do modelo obtida a partir do erro médio quadrático aferido dos dados de validação foi utilizada como critério de parada antecipada do treinamento.

A normalização dos dados foi feita de modo a conformar os valores a serem utilizados no treinamento da rede neural na faixa de 0 a 1, com o objetivo de tornar o processo de aprendizagem mais rápido e eficaz, reduzindo ainda os efeitos de escala e polarização [24].

O conjunto de dados utilizados para treinamento, validação e teste das redes neurais foram agrupados através de uma adaptação da técnica de janela deslizante [25].

Considerando que a resolução dos dados de energia é horária, existindo, portanto, 24 valores de energia por dia, os dados apresentados às entradas das redes neurais foram as informações de energia em n dias, onde n variou de 1 a 5.

Os dados a serem apresentados à entrada da rede foram transformados em imagem utilizando a técnica de RP, conforme explanado na seção II-D. Os valores de recorrência do gráfico variam de 0 a 1, e o tamanho da imagem resultante varia conforme o valor de n , assumindo as dimensões destacadas na tabela I.

Haja vista que o objetivo do trabalho é prever a quantidade de energia a ser gerada pelo sistema em análise no dia seguinte, foram propostas duas abordagens ao problema, mais precisamente no que diz respeito à estruturação dos dados a serem coletados na saída das CNNs:

- Previsão de energia gerada no dia seguinte hora a hora, tendo a rede, portanto, 24 saídas.
- Previsão de energia total gerada no dia seguinte, tendo a rede, portanto, 1 saída correspondente ao somatório de toda a energia gerada ao longo do dia.

D. Parâmetros das CNNs

O modelo proposto no presente trabalho busca utilizar o potencial principal da CNN, que é a extração de informações de dados bidimensionais, como imagens. A configuração da arquitetura da CNN proposta para o problema objeto deste trabalho está representada na fig. 6.

No modelo proposto, foram usadas camadas de convolução (Conv2D) com tamanho de filtros 3x3, onde o número de filtros foi fixado em 8. Associado à Conv2D foram aplicadas normalização de lotes, que é uma técnica utilizada para acelerar a convergência de redes profundas e para evitar o sobre-treinamento [26], e função de ativação Unidade Linear Retificada (*Rectified Linear Unit – ReLU*), a qual retorna 0 para todos as saídas com resultados negativos e o próprio valor para saídas com valores positivos. Já na camada de *pooling* (MaxPool), a dimensão utilizada foi 2x2, com número de *strides* variável, igualado ao valor de $n+1$. À camada de *Dropout*, cujo propósito é de evitar o sobre-treinamento da rede através da remoção temporária e




Fig. 6. Modelo proposto de CNN

aleatória de um percentual de neurônios das camadas escondidas, foi atribuído o valor de 20% de neurônios anulados randomicamente. Posteriormente, utilizou-se uma camada *Flatten*, que torna a matriz resultante das camadas anteriores de convolução e *pooling* em um formato linear. Então seguiu-se à implementação de camadas totalmente conectadas (*Dense*), cujo número de camadas foi variado entre 1 e 3 e o número de neurônios de cada camada foi variado entre 20 e 90, com acréscimo de 10 em 10. Após as camadas *Dense*, tem-se a camada de saída, com 24 ou 1 neurônio, dependendo da abordagem utilizada, conforme discriminado na Seção III-C. Todas as funções de ativação dos neurônios das Camadas *Dense* e da camada de saída foram ReLU. Os parâmetros de treinamento e propriedades da rede proposta estão resumidos na Tabela II.

O algoritmo utilizado para o treinamento das redes foi o Adam [27]. A métrica de avaliação de desempenho utilizada durante o treinamento foi o Erro Médio Quadrático (*Mean Squared Error* - MSE). Todos os treinamentos foram feitos com até 1.000 épocas, sendo que foi utilizado o critério de parada antecipada, baseada no desempenho do erro verificado nos dados de validação. Os dados de treinamento foram divididos em 32 mini lotes, que são subconjuntos do *dataset* de treinamento utilizados para reduzir o esforço computacional do algoritmo que ajusta os pesos da rede neural, além de tornar o treinamento mais rápido. No treinamento utilizando mini lotes, os parâmetros da rede são atualizados ao final da passagem dos dados contidos no subconjunto [28].

Durante o treinamento, os pesos sinápticos foram inicializados utilizando a técnica de inicialização de Glorot Normal (também conhecida como Inicialização de Xavier), o qual inicializa cada peso com uma gaussiana com média zero e com variância baseada nos números de conexões de entrada e de saída de cada camada, visando prevenir que as saídas das camadas da rede neural desapareçam ou explodam no caminho entre as diversas camadas da rede [29].

E. Validação Estatística

Dentre as diversas métricas utilizadas para verificação da precisão de um determinado preditor, este trabalho utiliza as seguintes metodologias de validação estatística, onde N é o número total de amostras, y é o valor real medido e \hat{y} é o valor previsto pela rede:

- Erro Médio Absoluto (*Mean Absolute Error* – MAE):

$$MAE = \frac{1}{N} \sum_{j=1}^N |y_j - \hat{y}_j| \quad (3)$$

- Erro Médio Quadrático (*Mean Squared Error* – MSE):

$$MSE = \frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2 \quad (4)$$

- Raiz do Erro Médio Quadrático (*Root Mean Squared Error* – RMSE):

$$RMSE = \sqrt{\frac{1}{N} \sum_{j=1}^N (y_j - \hat{y}_j)^2} \quad (5)$$

RESULTADOS E DISCUSSÃO

O pré-processamento dos dados, assim como a modelagem e treinamento das redes, foram feitos em *Python*, usando *Jupyter Lab*. As ferramentas para aprendizado de máquina utilizadas foram *Tensorflow* e *Keras*, além de *Scikit Learn* e outras bibliotecas básicas de *Python* usadas para processamento de dados e visualizações gráficas.

Tanto para o caso de saída desejada sendo a energia gerada no dia seguinte, hora a hora, como para saída desejada sendo a energia total gerada no dia seguinte, diversas configurações de CNNs foram treinadas com variação no valor da janela n , conforme detalhado na Seção III-C, no número de camadas totalmente conectadas e no número de neurônios em tais camadas, conforme discriminado na Seção III-D. Então, para cada configuração de rede foram realizadas 100 repetições de treinamento (100 inicializações dos pesos das redes), com o devido registro dos MAE e RMSE de cada treinamento, bem como armazenamento dos pesos da rede com melhor performance em termos de RMSE.

Para a validação do modelo proposto no presente trabalho, foi feita a comparação do resultado obtido por meio do uso de transformação de séries temporais em imagens aplicadas a redes CNN 2D com modelos de redes MLP e CNN 1D, estes sem transformação da série temporal para imagens.

TABELA I. DIMENSÃO DAS IMAGENS DE ENTRADA DAS CNNs

Valor de n	Dimensão da Imagem
1	24x24
2	48x48
3	72x72
4	96x96
5	120x120

TABELA II. PARÂMETROS DE TREINAMENTO E PROPRIEDADES

Item	Descrição
Número de épocas	1.000
Tamanho dos Mini lotes	32
Algoritmo de Treinamento	ADAM
Tamanho dos filtros da camada Convolutacional	3x3
Número de filtros da camada Convolutacional	8
Tamanho da janela de pooling	2x2
Número de Camadas <i>Dense</i>	1 a 3
Número de Neurônios nas Camadas <i>Dense</i>	20 a 90
Função de Ativação	ReLU

A. Resultados

Os erros médios (considerando todas os treinamentos realizados) e mínimo (considerando o melhor resultado entre todos os treinamentos) para cada uma das redes propostas (MLP, CNN 1D e CNN 2D), com as configurações de saída de energia 24 horas e de saída do somatório da energia, estão expostos nas tabelas III e IV, respectivamente. Os erros foram calculados com os valores normalizados dos dados de saída e considerando apenas a base de teste aplicada nas redes, que é base que deve ser usada para avaliar desempenho e capacidade de generalização das redes. Já nas tabelas V e VI estão apresentados os RMSE calculados com base nos valores reais dos dados, sem normalização.

B. Discussão

O treinamento das redes propostas neste trabalho apresentou custo computacional equiparado ao custo relativo ao treinamento das redes MLP e CNN 1D nos casos em que o valor de n foi igual a 1 ou 2. Para valores de n maiores do que 2, o custo computacional aumentou, haja vista que a dimensão das imagens a serem tratadas pela rede proposta cresceu proporcionalmente, conforme explanado na tabela I.

Todos os valores dos erros mínimos obtidos nas tabelas III a VI correspondem a redes cujos dados de entrada agregaram apenas as 24 horas de energia anteriores ao dia a ser previsto, ou seja, n igualado a 1 resultou em redes com menores erros se comparados aos erros das redes com n maior que 1. Este comportamento foi observado em todos os tipos de rede testados (MLP, CNN 1D e CNN 2D).

É possível verificar que, em valores médios, a metodologia proposta no presente trabalho tem um desempenho superior, tanto em MAE quanto em RMSE, quando comparada às metodologias consolidadas para previsão de geração de energia fotovoltaica que utilizam MLP e CNN 1D.

TABELA III. SAÍDA ENERGIA 24 HORAS - NORMALIZADO

Tipo de Rede	Erro Médio		Erro Mínimo	
	MAE	RMSE	MAE	RMSE
MLP	0,0763	0,1557	0,0425	0,0842
CNN 1D	0,0917	0,1845	0,0416	0,0856
CNN 2D	0,0700	0,1298	0,0453	0,0873

TABELA IV. SAÍDA ENERGIA SOMATÓRIO - NORMALIZADO

Tipo de Rede	Erro Médio		Erro Mínimo	
	MAE	RMSE	MAE	RMSE
MLP	0,1973	0,2389	0,0933	0,1312
CNN 1D	0,2254	0,2649	0,0902	0,1328
CNN 2D	0,1542	0,1845	0,0905	0,1288

TABELA V. RMSE DE SAÍDA ENERGIA 24 HORAS - REAL

Tipo de Rede	Erro Médio	Erro Mínimo
MLP	2,3226	1,2562
CNN 1D	2,7529	1,2767
CNN 2D	1,9373	1,3024

TABELA VI. RMSE DE SAÍDA ENERGIA SOMATÓRIO - REAL

Tipo de Rede	Erro Médio	Erro Mínimo
MLP	24,1796	13,2758
CNN 1D	26,8071	13,4370
CNN 2D	18,6721	13,0302

No que diz respeito a valores mínimos de erro, as séries temporais transformadas em imagens aplicadas em redes CNN 2D apresentaram índices competitivos com os outros tipos de rede, quando não melhores. Importante destacar o desempenho da estrutura cuja saída é o somatório da energia das 24 horas do dia predito, onde o menor RMSE observado da rede CNN 2D é 1,85% menor do que o erro da rede MLP e 3,03% menor do que o erro da rede CNN 1D.

As fig. 8 e 9 mostram, a título de ilustração, gráficos comparativos da energia total gerada pela rede elaborada com base na metodologia proposta, com a saída correspondente ao somatório de energia, em dois dias aleatórios da base de dados de teste. Através desses gráficos, é possível observar que, nos dias escolhidos (03/08 e 20/11/2022), a energia prevista através da CNN 2D foi mais próxima da energia real gerada pelo sistema fotovoltaico do que os outros métodos analisados (MLP e CNN 1D), significando uma melhor performance da metodologia ora proposta em comparação com as outras redes mencionadas.

Considerando o caso da fig. 8, a energia total gerada pelo sistema fotovoltaico no dia 03/08/2022 foi de 96,73 KWh, sendo que a energia prevista pela CNN 2D para o mesmo dia foi de 91,08 KWh, o que representa uma diferença entre o valor medido e o valor predito, ou erro, de 5,64 KWh. Já as redes MLP e CNN 1D previram respectivamente o total de energia de 82,36 e 84,46 KWh, significando erros em relação ao valor real de energia de 14,37 e 12,27 KWh. Já no fig. 9, para o dia 20/11/2022, a energia gerada pelo sistema fotovoltaico foi de 78,17 KWh, enquanto as energias previstas pelas redes CNN 2D, CNN 1D e MLP foram respectivamente iguais a 73,44, 69,56 e 69,78 KWh, e os erros correlatos foram iguais a 4,73, 8,61 e 8,39 KWh. As tabelas VII e VIII apresentam o resumo dos valores de energia medidos ou previstos, bem como o erro calculado.

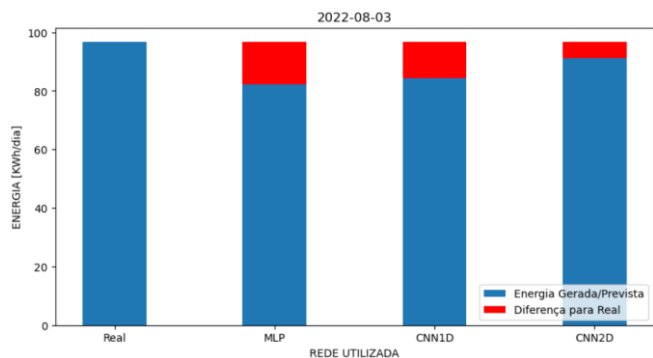


Fig. 8. Energia total gerada e prevista no dia 03/08/2022.

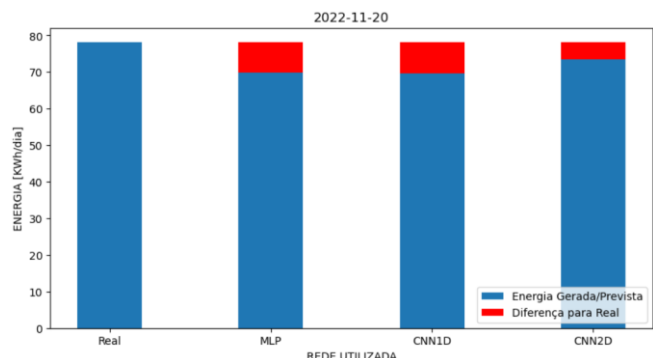


Fig. 9. Energia total gerada e prevista no dia 20/11/2022.

TABELA VII. ERRO DE ENERGIA – DIA 03/08/2022

Tipo de Rede	Energia (KWh)	Erro (KWh)
REAL	96,73	-
MLP	82,36	14,37
CNN 1D	84,46	12,27
CNN 2D	91,08	5,64

TABELA VIII. ERRO DE ENERGIA – DIA 20/11/2022

Tipo de Rede	Energia (KWh)	Erro (KWh)
REAL	78,17	-
MLP	69,78	8,39
CNN 1D	69,56	8,61
CNN 2D	73,44	4,73

CONCLUSÃO

Prever a energia gerada em um sistema fotovoltaico é um passo importante para o sistema de energia elétrica, porém pode ser desafiador, muito em virtude da intermitência dos fatores climáticos e da irradiação solar. Nesse contexto, este trabalho buscou apresentar uma metodologia para prever, de maneira mais acurada, a energia gerada pelo sistema fotovoltaico instalado na UFPA, nas dependências do CEAMAZON, onde os resultados obtidos demonstraram a viabilidade da transformação de séries temporais de geração de energia fotovoltaica em imagens, através do uso de RP sem limiar, com aplicação em CNNs bidimensionais para previsão da energia a ser gerada nas 24 horas posteriores.

A metodologia proposta conseguiu obter valores de RMSE similares às metodologias comumente empregadas em problemas similares, como MLP e CNN 1D, em alguns casos até apresentando erro menor do que as técnicas mais difundidas. Isto demonstra que as CNNs podem gerar resultados mais próximos ao valor real quando tratam dados em formato tabular, como os utilizados neste estudo, em que as séries temporais de energia elétrica gerada pelo sistema fotovoltaico em análise foram transformadas em imagens, com a utilização de RP.

Em trabalhos futuros, podem ser acrescentadas às entradas das redes os dados meteorológicos mais relevantes, tanto utilizando variáveis coletadas localmente, quanto usando dados provenientes de sistemas de monitoramento espacial, como satélites, visando gerar previsões mais precisas. Pode-se também ampliar a comparação dos resultados obtidos com a rede proposta com outras metodologias consolidadas, como Regressão de Vetor de Suporte (*Support Vector Regressor – SVR*) e LSTM. Além disso, é possível também criar sistemas híbridos, mesclando a metodologia proposta neste trabalho com redes LSTM, que foram projetadas para processar dados sequenciais, com grande capacidade de reter informações anteriores, sendo utilizadas em trabalhos recentes para solucionar problemas relacionados a predição de séries temporais [30], podendo, desta forma, incluir um aumento na acurácia já alcançada pelo modelo ora proposto. Outra abordagem possível é utilizar outras técnicas de transformação de séries temporais em imagens, a exemplo de *Gramian Angular Field* e *Markov Transition Field*. Ademais,

REFERÊNCIAS

- [1] United Nations, The 2030 Agenda and the Sustainable Development Goals: An opportunity for Latin America and the Caribbean (LC/G.2681-P/Rev.3), Santiago, 2018.
- [2] SMIL, V. "Distributed Generation and Megacities: Are Renewables the Answer?". *IEEE Power and Energy Magazine*, Nova York, vol. 17, n. 2, p. 37-41, mar. 2019.
- [3] AGOUA, X. G.; GIRARD, R.; KARINIOTAKIS, G. Short-term spatio-temporal forecasting of photovoltaic power production. *IEEE Transactions on Sustainable Energy*, v. 9, n. 2, p. 538-546, abr. 2018.
- [4] ANTONANZAS, J.; OSORIO, N.; ESCOBAR, R.; URRACA, R.; MARTINEZ-DE PISON, F. J.; ANTONANZAS-TORRES, F. Review of photovoltaic power forecasting. *Solar Energy*, v. 136, p. 78-111, jul. 2016.
- [5] AGGA, A.; ABBOU, A.; LABBADI, M.; EL HOUM, Y. Convolutional Neural Network (CNN) Extended Architectures for Photovoltaic Power Production Forecasting. *In: International Conference on Smart Grid and Clean Energy Technologies (ICSGCE)*, n. 9, 2021, Sarawak, Malaysia, pp. 104-108.
- [6] SURESH, V.; JANIK, P.; REZMER, J.; LEONOWICZ, Z. Forecasting Solar PV Output Using Convolutional Neural Networks with a Sliding Window Algorithm. *Energies*, v. 13, n. 3, p. 723, fev. 2020.
- [7] LIM, S.-C.; HUH, J.-H.; HONG, S.-H.; PARK, C.-Y.; KIM, J.-C. Solar Power Forecasting Using CNN-LSTM Hybrid Model. *Energies*, v. 15, n. 21, p. 8233, nov. 2022.
- [8] QING, X.; NIU, Y. Hourly day-ahead solar irradiance prediction using weather forecasts by LSTM. *Energy*, v. 148, p. 461-468, fev. 2018.
- [9] HOSSAIN, M. S.; MAHMOOD, H. Short-Term Photovoltaic Power Forecasting Using an LSTM Neural Network and Synthetic Weather Forecast. *IEEE Access*, v. 8, p. 172524-172533, out. 2020.
- [10] TOVAR, M.; ROBLES, M.; RASHID, F. PV Power Prediction, Using CNN-LSTM Hybrid Neural Network Model. Case of Study: Temixco-Morelos, México. *Energies*, 13, n. 24, p. 6512, dez. 2020.

- [11] SCHIERMEIER, Q.; TOLLEFSON, J.; SCULLY, T.; WITZE, A.; MORTON, O. Energy Alternatives: Electricity Without Carbon. **Nature**, v. 454, p. 816-823, ago. 2008.
- [12] SMESTAD, Greg P. **Optoelectronics of Solar Cells**. 1. ed. Bellingham: SPIE, 2002. 118 p.
- [13] WANG, G.; SU, Y.; SHU, L. One-day-ahead daily power forecasting of photovoltaic systems based on partial functional linear regression models. **Renewable Energy**, v. 96-A, p. 469-478, out. 2016.
- [14] ANTONANZAS, J. et al. Review of photovoltaic power forecasting. **Solar Energy**, v. 136, p. 78-111, out. 2016.
- [15] ALKHAYAT, G.; MEHMOOD, R. A review and taxonomy of wind and solar energy forecasting methods based on deep learning. **Energy and AI**, v. 4, p. 100060, jun. 2021.
- [16] HAYKIN, Simon. **Neural Networks and Learning Machines**. 3. ed. Hamilton: Person Education, 2009. 937 p.
- [17] DA SILVA, Ivan Nunes; SPATTI, Danilo Hernani; FLAUZINO, Rogério Andrade. **Redes Neurais Artificiais para Engenharia e Ciências Aplicadas**. São Paulo: Artliber, 2010. 399 p.
- [18] GOODFELLOW, I.; BENGIO, Y.; COURVILLE, A. **Deep Learning**. MIT Press, 2016. Disponível em: <https://www.deeplearningbook.org>. Acesso em 07 abr. 2023.
- [19] LECUN, Y.; BENGIO, Y.; HINTON, G. Deep Learning. **Nature**, v. 521, p. 436-444, mai. 2015.
- [20] MORETTIN, Pedro A.; TOLOI, Clélia, M. C. **Análise de Séries Temporais**. 2. ed. São Paulo: Edgar Blucher, 2006, 538 p.
- [21] ECKMANN, J.-P.; KAMPHORST, S. O.; RUELLE, D. Recurrence Plots of Dynamical Systems. **Europhysics Letters**, v. 4, n. 9, p. 973, nov. 1987.
- [22] SIPERS, A; BORM, P; PEETERS, R. Unthresholded Recurrence Plots for Complex-Valued Representations of Narrow Band Signals. In: MARWAN, N., RILEY, M., GIULIANI, A., WEBBER, Jr., C. (eds). **Translational Recurrences**. Chicago: Springer, 2014. p. 31-53.
- [23] Tabora, J.M. et. al. Hybrid System Assessment in On-Grid and Off-Grid Conditions: A Technical and Economical Approach. **Energies**, v. 14, p. 5284, ago. 2021.
- [24] SINGH, D.; SINGH, B. Investigating the impact of data normalization on classification performance. **Applied Soft Computing**, v. 97, parte B, dez. 2020.
- [25] LAZZERI, Francesca. **Machine Learning for time series forecasting with Python®**. 1. ed. Indianapolis: Willey, 2021, 206 p.
- [26] LIU, M. et al. Deep Learning based on Batch Normalization for P300 signal detection. **Neurocomputing**, v. 275, p. 288-297, jan. 2018.
- [27] KINGMA, D.; BA, J. Adam: A method for Stochastic Optimization. arXiv preprint arXiv:1412.6980. doi: 10.48550/ARXIV.1412.6980.
- [28] BOTTOU, L. Large-scale Machine Learning with Stochastic Gradient Descent. In: Lechevallier, Y., Saporta, G. (eds) **Proceedings of COMPSTAT'2010**. Paris: Springer, 2010.
- [29] GLOROT, X.; BENGIO, Y. Understanding the difficulty of training deep feedforward neural networks. **Proceedings of the thirteenth international conference on artificial intelligence and statistics. JMLR Workshop and Conference Proceedings**, 2010.
- [30] SIAMI-NAMINI, S.; TAVAKOLI, N.; SIAMI NAMIN, A. A Comparison of ARIMA and LSTM in Forecasting Time Series, 2018 17th IEEE International Conference on Machine Learning and Applications (ICMLA), Orlando, FL, USA, 2018, pp. 1394-1401, doi: 10.1109/ICMLA.2018.00227.